

**Tobias Müller ; Klaus Lange ; Andreas Breuer ; Olaf Krieger ;
Thomas Form**

**Automatische erfahrungsbasierte Diagnose aus Felddaten
mit neuronalen Netzen**

**Automatic and Experience-based Diagnostics using
Distributed Data and Neural Networks**

Veröffentlicht: 23.01.2008

<http://www.digibib.tu-bs.de/?docid=00021901>

Auch erschienen in:

12. Internationaler Kongress "Elektronik im Kraftfahrzeug", S.
593-605, VDI Verlag 2007, ISBN 978-3-18-092000-9

Automatische erfahrungsbasierte Diagnose aus Felddaten mit neuronalen Netzen

Automatic and Experience-based Diagnostics using Distributed Data and Neural Networks

Dipl.-Ing. **T. Müller**, TU Braunschweig, Inst. für Regelungstechnik, Braunschweig;

Dipl.-Ing. **K. Lange**, Dipl.-Ing.(FH) **A. Breuer**, Dipl.-Ing. **O. Krieger**, Volkswagen AG, Wolfsburg;

Prof. Dr. **Th. Form**, TU Braunschweig, Lehrstuhl für elektr. Fahrzeugsysteme, Braunschweig

Kurzfassung

Der zunehmende Einsatz komplexer mechatronischer Systeme in Kraftfahrzeugen erfordert neue Methoden und Vorgehensweisen für eine zielsichere Diagnose in der Kfz-Werkstatt. Mit neuen technischen Diagnoseverfahren soll die Erkennung und Bewertung von fehlerhaften Systemen im Kfz verbessert werden. Ein neuer Ansatz ist das Lernen aus Reparaturfalldaten mittels Neuronaler Netze. Diese Technologie der Künstlichen Intelligenz ermöglicht es aus den Reparaturfalldaten Zusammenhänge und Abhängigkeiten zu lernen und das erlernte Wissen für zukünftige Reparaturfälle zu nutzen.

Abstract

Incremental insertion of complex mechatronic systems in the vehicles leads to a serious need of a parallel development of new methods and approaches for a safe-based diagnosis in the vehicles' factory. The idea behind is to improve both of detection and evaluation processes of faulty systems using new techniques for the diagnosis process. The adopted approach is to enable the diagnostic system to learn from the data of the past repairing cases based on neural networks, which involve artificial intelligence methodologies. These methodologies enable the diagnostic system to learn -from the coherence and independences involved in the past data- the needed know how, which can be further used for future repairing cases.

1 Einleitung

Moderne Fahrzeuge verfügen über eine Vielzahl an Steuergeräten und elektronischen Komponenten, die ein unkompliziertes, bequemes und sicheres Fahren gewährleisten. Dies

hat in der Vergangenheit zu einem starken Anstieg der Komplexität geführt, ohne dass die in der Praxis eingesetzten Diagnosesysteme mit dieser Entwicklung Schritt gehalten haben. Die Folge ist, dass eine in der Werksatt durchgeführte Fehlerdiagnose in über 60 Prozent der Fälle den Fehler nicht findet, vgl. [1]. Hierdurch steigen die Fehlersuchzeiten und die Fehltauschrate¹. Während bei Steuergeräten der ersten Generation jede Funktion genau einem Steuergerät zugeordnet war, werden Funktionen heute auf diverse Steuergeräte verteilt. Zusätzlich wird die Diagnose durch die Tatsache erschwert, dass ein Symptom nicht selten mehrere Ursachen hat, und eine Ursache oft zu mehreren Symptomen führt, vgl. [2], [3].

2 Hintergrund und Ausgangssituation

Die meisten heute eingesetzten Steuergeräte sind eigendiagnosefähig. Das bedeutet, sie besitzen Diagnoseroutinen innerhalb der Steuergerätesoftware, welche die Sensoren und Aktoren gegeneinander plausibilisieren. Unter anderem kommen hier modellbasierte Diagnoseverfahren zum Einsatz [5]. Wird vom System eine Störung erkannt, so wird ein Ereignisspeichereintrag (DTC²) hinterlegt, der über eine Diagnoseschnittstelle aus dem Fahrzeug ausgelesen werden kann [4].

Im Gegensatz zur Eigendiagnose (On-Board-Diagnose) versteht man unter Off-Board-Diagnose-Systemen eine Klasse von Systemen, die in der Werkstatt an ein Fahrzeug angeschlossen werden und von außen auf die Systeme im Fahrzeug zugreifen. Sie haben die Möglichkeit, Ereignisspeichereinträge aller vorhandenen Fahrzeugsysteme auszulesen und dem Kundendienstmitarbeiter in lesbarer Form anzuzeigen.

Leistungsfähige Diagnosesysteme sollen dem KD-Mitarbeiter nicht nur alle Informationen aus den einzelnen Steuergeräten anzeigen, sondern ihn zusätzlich bei der Fehlersuche aktiv

¹ Fehltauschrate = Verhältnis von getauschten aber nicht defekten Teilen zu getauschten und defekten Teilen.

² DTC – engl. Diagnostic Trouble Code

unterstützen. Ein Beispiel hierfür im Kundendienst von Volkswagen ist die Geführte Fehlersuche (GFS). Die GFS verwendet Fehlersuchprogramme auf Basis von Entscheidungsbäumen, welche von Experten erstellt, in verschiedene Sprachen übersetzt und weltweit an die Anwender verteilt werden. Hier wird für jeden Fehlercode, der in einem Fahrzeug auftreten kann, ein Fehlersuchprogramm erstellt. Eine besondere Schwierigkeit besteht hierbei in der Abdeckung aller Varianten eines Fahrzeuges, welche sich durch die zahlreichen Ausstattungsmöglichkeiten ergeben. Dies ist bei der Erstellung der Fehlersuchprogramme zu berücksichtigen. So äußert sich derselbe Fehler in den unterschiedlichen Fahrzeugvarianten jeweils in anderer Art und auch Prüf- und Reparaturanweisungen können stark variieren. Bereits im Voraus alle möglichen Fehlerquellen zu erkennen und abzudecken ist eine weitere Schwachstelle solcher manuell erstellter Fehlersuchprogramme.

Die genannten Punkte führen in der Praxis zwangsläufig zu Kompromissen, da das Berücksichtigen aller möglichen Fehlerquellen sowie aller Fahrzeugvarianten nur mit erheblichem Aufwand beherrschbar ist. Insbesondere der bereits genannte Anstieg an Komplexität als auch die Tendenz zu verteilten Funktionen führen damit vermehrt zu reduzierten und unspezifischeren Fehlersuchprogrammen (z. B. „Suche nach Stromlaufplan“).

Ein wichtiger Schritt zur Verbesserung der Diagnosequalität ist die Möglichkeit die Vorgänge im Feld auszuwerten, wie z. B. durch die Einführung einer Datenbank für Felddaten. So könnten z.B., die für einen Reparaturfall relevanten Daten wie Ereignisspeichereinträge u.s.w., aufgezeichnet werden. Mit den heute verfügbaren Informationen werden bereits Auswertungen zur Verbesserung der Prüfabläufe durchgeführt. Dieser Vorgang der Auswertung, wie auch die anschließende Verbesserung der Fehlersuchprogramme wird jedoch manuell vorgenommen und lässt sich nicht mit vertretbarem Aufwand automatisieren. Daher können über diese Vorgehensweise nur eine geringe Zahl an Prüfprogramme verbessert werden. An diesem Punkt setzt das in diesem Beitrag nachfolgend beschriebene erfahrungsbasierte Diagnosesystem an.

3 Die Idee

Weltweit existieren mehrere zehntausend KFZ-Werkstätten mit insgesamt über hunderttausend Mitarbeitern. Aufgrund dieses enormen Potentials, ist der Austausch an Erfahrung zwischen den einzelnen Werkstätten eine Herausforderung. Dies soll mit einem Beispiel veranschaulicht werden.

Im Fall eines komplexen Reparaturproblems für dessen Lösung ein KD-Mitarbeiter A einiges an Fehlersuchzeit und auf Verdacht getauschte Teile aufgewendet hat, bedeutet dies für den KD-Mitarbeiter B einer anderen Werkstatt mit demselben Problem, denselben Aufwand zu investieren. KD-Mitarbeiter B profitiert folglich nicht von der Erfahrung des KD-Mitarbeiters A. Wäre es möglich, die einmal gemachten Erfahrungen immer zur Verfügung zu haben, bestände ein großes Einsparpotential.

Das Ziel sollte daher sein, aus Reparaturfällen zu lernen und das erlangte Wissen für zukünftige Reparaturfälle zu nutzen. Da auch hier analog zur GFS die Menge der Daten und das daraus erlangbare Wissen groß ist, kann sowohl das Lernen als auch die Anwendung nur dann von gewinnbringender Effizienz sein, wenn der gesamte Prozess automatisch durchführbar ist.

4 Problemanalyse

Für ein lernendes System ist die Art und die Qualität der vorhandenen Daten von entscheidender Bedeutung. Gelernt werden soll aus den Reparaturfällen in den Werkstätten. Auch wenn eine Reparatur in der Werkstatt ein iterativer Prozess ist, so kann der Informationsgehalt auf eine Symptombild – Reparaturmaßnahmenrelation komprimiert werden (vgl. Bild 1). In einem Symptombild werden alle während der Reparatur festgestellten Symptome zusammengefasst. Hierzu zählen nicht nur technisch leicht und eindeutig erfassbare Symptome wie DTCs sondern auch subjektiv wahrgenommene Symptome welche in einer geeigneten Weise codiert wurden. Zu den Maßnahmen werden Aktionen des KD-Mitarbeiters, wie getauschte Teile oder Arbeitspositionen zusammengefasst. Auf diese Weise kann eine Reparatur als abgeschlossenen Prozess mit einem Symptombild als Eingangsgröße und einer Reihe von Reparaturmaßnahmen als Ausgangsgröße betrachtet werden. Das dem Prozess zugrundeliegende System ist hierbei das jeweilige Fahrzeug an sich. Nun werden keinesfalls immer absolut baugleiche Fahrzeuge repariert, vielmehr sind alle Fahrzeuge, selbst wenn sie von derselben Klasse sind, aufgrund der möglichen Varianten unterschiedlich. Als eine weitere Eingangsgröße des Reparaturprozesses sind folglich die fahrzeugspezifischen Eigenschaften als Kontext zu betrachten. Kontext und Symptombild werden hierbei zu einem Eingangsvektor zusammengefasst. Die resultierende Lernaufgabe besteht nun darin, aus den vorhandenen Daten ein Modell abzuleiten, das die beobachteten Eingangs- und Ausgangsgrößen bestmöglichst abbildet.

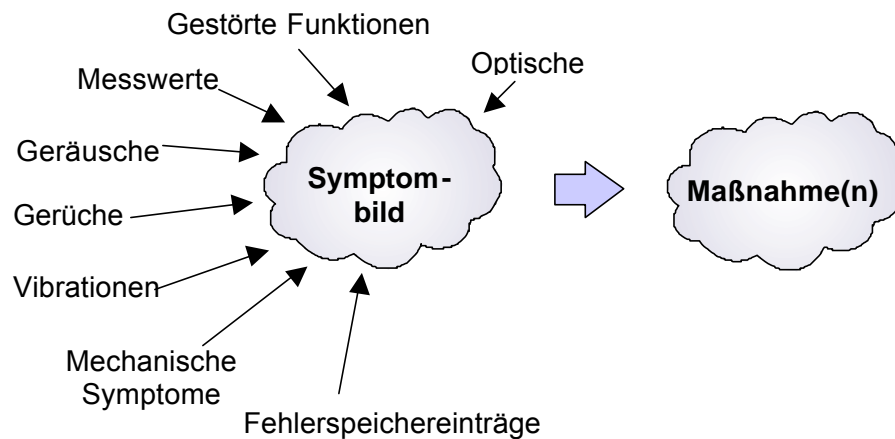


Bild 1: Abstraktion aus der zu lernenden Erfahrung.

Die Untersuchung verschiedener Technologien am IFR³ hat ergeben, dass Künstliche Neuronale Netze (KNN) hierfür besonders gut geeignet sind. Auf eine Einführung in KNN wird an dieser Stelle verzichtet und auf [6] verwiesen. Eine wichtige Eigenschaft der KNN bei der zugrundeliegenden Aufgabe ist das Erkennen von Mustern in den vorhandenen Trainingsdaten (Patterns). Eine weitere wichtige Eigenschaft ist die Fähigkeit zu generalisieren, d. h. dass KNN ist in der Lage auch für Symptombilder, die nicht Teil der Trainingspatterns sind eine Aussage treffen zu können.

5 Realisierung

Ziel der Realisierung ist ein geschlossener Diagnoseprozess, der eine automatische Rückführung und Nutzung von Erfahrung ermöglicht. Ein prinzipielles Datenflussdiagramm ist in Bild 2 dargestellt. Im Werkstatt-Prozess sind alle Prozesse innerhalb einer Werkstatt zusammenzufassen. Eine Auswahl der entstehenden Daten, gemeint sind hier vor allem Reparaturfalldaten, sind in die Datenbank zu übertragen. Aus dem Datenbestand ist nun das Lernsystem zu speisen, welches aus der Vielzahl der Daten, wie vorhergehend beschrieben,

³ Institut für Regelungstechnik, TU Braunschweig

Modelle erzeugt. Diese Modelle sind anschließend als Diagnosewissen ebenfalls in eine Datenbank zu übertragen, welche die Daten an die Werkstätten verteilt. Es handelt sich somit um einen geschlossenen Prozess, dessen Rückkopplung weitere Eigenschaften ausbildet. Hierdurch würde für bisher unbekannte Reparaturprobleme, durch die Gesamtheit der KD-Mitarbeiter, ein automatischer, iterativer Problemlösungsprozess entstehen. Dieser soll nachfolgend näher beschrieben werden.

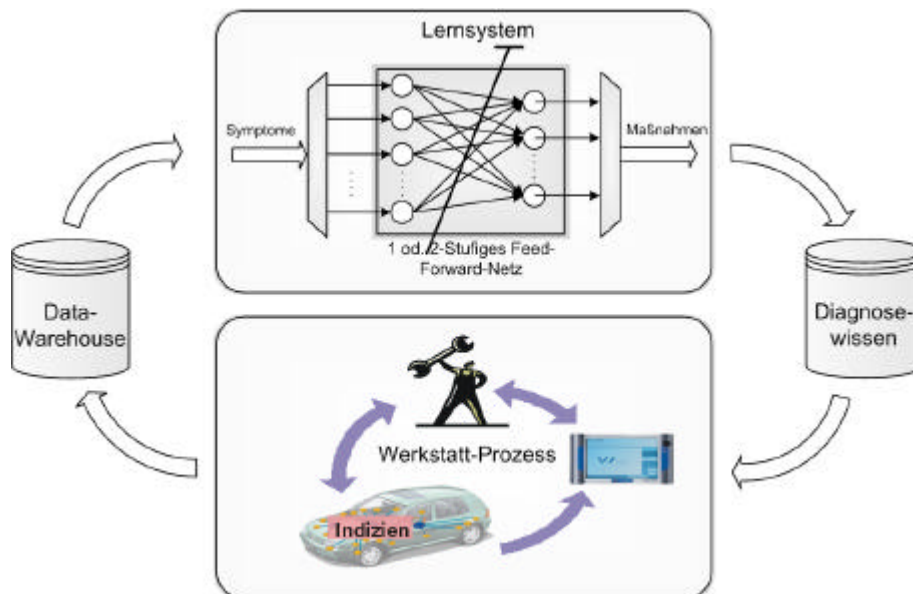


Bild 2: Datenflussdiagramm des Diagnose-Prozesses.

Würde in einer Werkstatt ein neues bisher in den Datenbeständen unbekanntes Reparaturproblem auftreten, so besteht für dieses erste Auftreten im erlernten Modell kein Diagnosewissen. Eine zielgerichtete Diagnose würde nicht möglich sein. Der betreffende KD-Mitarbeiter müsste das Problem dann mit den ihm vorhandenen Mitteln lösen (z. B. Fehlersuchprogramme etc.). Weiterhin wird davon ausgegangen, dass in dieser ersten Problemlösung mehrere, auch zum Teil nicht erfolgreiche Reparaturmaßnahmen erbracht werden, die anschließend in den Datenbestand einfließen. Im folgenden Schritt würde das Lernsystem erneut aus den Datenbeständen des Datawarehouse lernen und das Diagnosewissen optimieren. Würde nun dieses Problem in einer anderen Werkstatt erneut auftreten, so könnte das Diagnosesystem aufgrund der veränderten Modelle bereits eine zielgerichtete Diagnose stellen. Diese könnte aufgrund der Datenlage jedoch noch unscharf sein. Der betreffende KD-Mitarbeiter wird also im Regelfall eine Auswahl an den vorgeschlagenen Diagnosen treffen müssen. Wäre die „Reparaturlösung“ dabei Teil der Diagnosen, so würde die Menge der durchgeführten, nicht erfolgreichen

Reparaturmaßnahmen im Mittel kleiner. Bereits nach ein paar wenigen Iterationen würde so automatisch die beste Reparaturlösung für das neue Problem gefunden. Nach dem gleichen Funktionsprinzip würden auf diese Weise nicht nur neue Problemlösungen gefunden sondern auch Veränderungen automatisch adaptiert werden.

6 Das Lernsystem

Eine entscheidende Rolle in dem beschriebenen Diagnoseprozess kommt dem Lernsystem zu. Eine nahe liegende Realisierung eines Lernsystems mit KNN ist in Bild 3 dargestellt. Es wird ein großes Feed-Forward-Netz ohne oder mit einem Hiddenlayer erzeugt. Die Zahl der Eingangsneuronen entspricht dabei der Größe des Eingangsvektors (Anzahl der möglichen Symptome und Kontextinformationen) und analog die Zahl der Ausgangsneuronen der Größe des Ausgangsvektors (Anzahl der möglichen Reparaturmaßnahmen).




Bild 3: Lernsystem mit einem Neuronalen Netz.

Bei der Realisierung eines solchen Systems hat sich gezeigt, dass schnell ein zu großes Netz entsteht. Selbst wenn bei einem Fahrzeug der Mittelklasse ausschließlich DTCs als Symptome und getauschte Ersatzteile als Maßnahmen verwendet werden, entsteht ein Netz mit mind. 3.000 Eingangs- und 10.000 Ausgangsneuronen. Die daraus resultierende Anzahl der Verbindungen liegt je nach Anzahl der Hiddenlayer zwischen 30.000.000 und 50.000.000. Dies sind zu viele, um ein solches Netz effizient erzeugen und trainieren zu können. Hinzu kommt, dass eine Maßnahme in den meisten Fällen lediglich von ein paar wenigen Symptomen abhängt und somit der größte Teil der Verbindungen zu einem Ausgangsneuron ein Gewicht nahe Null besitzen. Genau diese große Zahl an nicht relevanten Verbindungen führt jedoch zu Einbußen in der Qualität des Netzes. Sinnvoller ist es, mehrere kleinere und besser handhabbare Netze zu erzeugen.

Die Unterteilung in mehrere kleinere Netze ist jedoch kein triviales Problem. Um die positiven Eigenschaften der Netze, wie Mustererkennung und Generalisierung beizubehalten, sollten in einem Netz möglichst diejenigen Symptome und Maßnahmen zusammengefasst werden, zwischen denen es einen Zusammenhang gibt. Ein Maß für den Zusammenhang ist die aus der Statistik bekannte Signifikanz. Signifikanz bedeutet dabei, dass es mit einer gewissen Irrtumswahrscheinlichkeit p einen Zusammenhang zwischen Symptom und Maßnahme gibt. Ein p -Wert von 1 bedeutet eine 100%-tige Irrtumswahrscheinlichkeit für den Zusammenhang (es gibt also keinen Zusammenhang) und ein p -Wert von 0 bedeutet eine 0%-tige Irrtumswahrscheinlichkeit (es gibt einen eindeutigen Zusammenhang).

7 Clustern von Künstlichen Neuronen Netzen


Für eine sinnvolle Unterteilung in kleinere Netze wurde ein spezielles, nachfolgend beschriebenes Clusterverfahren entwickelt.

Der erste Schritt ist das Finden von signifikanten Symptomen für jede Maßnahme. Mögliche Methoden für einen solchen Signifikanztest sind der χ^2 -Test (Chi-Quadrat-Test) und der exakte Test nach Fisher. Wird ein solcher Signifikanztest sukzessiv über den gesamten Datenbestand für alle Symptome und Maßnahmen durchgeführt, ergibt sich eine

Schritt1: Signifikanzmatrix

	S1	S2	S3	S4	...	Sxx
M1	1	0,02	1	1
M2	0,01	1	1	1
M3	1	1	0,01	0,01
M4	1	1	1	0,01
...
Mxx

Schritt 3: Cluster



Schritt 2:
Graphen

Bild 4: Vereinfacht dargestellter Clusterprozess

Signifikanzmatrix (Beispiel oben in Bild 4). Aus der Signifikanzmatrix kann nun abgelesen werden, welche Symptome auf welche Maßnahme mit welcher Irrtumswahrscheinlichkeit einen Einfluss hat.

In Schritt 2 wird ein Threshold (Grenzwert) für den p-Wert definiert (üblicherweise 5%). Alle Signifikanzen mit einem p-Wert unter dem Threshold (in Bild 4 farbig hinterlegte Felder) werden nun als direkte Zusammenhänge interpretiert und mit einer Kante (Graphentheorie) verbunden.




Bild 5: Resultierendes Cluster und Erzeugung des KNN.

In Schritt 3 wird nach Symptomen gesucht, die in mehreren Graphen gleichzeitig vorkommen. Diese Graphen werden anschließend über das gemeinsam vorkommende Symptom zu einem Graphen vereint. Bild 4 unten und Bild 5 oben verdeutlichen diesen Vorgang. Hier werden über den Knoten S4, die zwei Graphen mit M3 und M4 verbunden. Der resultierende Graph ist in Bild 5 oben dargestellt. Nach dieser Zusammenfassung entspricht jeder Graph einem Cluster.

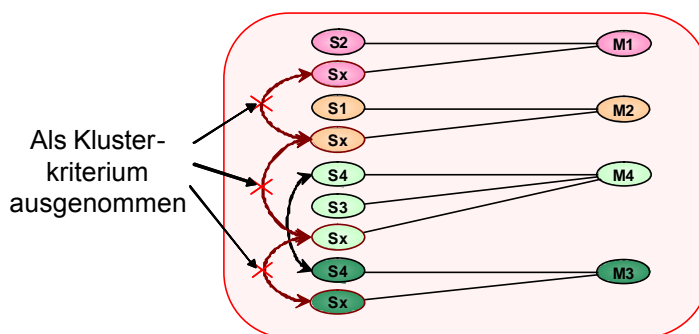


Bild 6: Ausnahmekriterium der Klusterung.

Eine Ausnahme zu Schritt 3 bilden sehr häufig vorkommende Symptome. Existiert ein Symptom, das abhängig oder unabhängig zum jeweiligen Problem sehr häufig auftritt, so führt eine konsequente Zusammenführung der Graphen über dieses Symptom nach Schritt 3 zu einem Riesengraph/-cluster (vgl. Bild 6). Aus diesem Grund wird vor der Zusammenführung geprüft, in wie vielen Graphen ein Symptom vorkommt. Übersteigt die Anzahl einen zuvor definierten Threshold, so wird dieses Symptom nicht für die Zusammenführung von Graphen herangezogen.

Für jedes so gefundene Cluster wird nun in Schritt 4 ein eigenes KNN erstellt, wobei jedes Symptom durch ein Eingangsneuron und jede Maßnahme durch ein Ausgangsneuron repräsentiert wird. Die Vernetzung der Neuronen erfolgt dabei wie bereits in der vorhergehenden Realisierung Feed-Forward (vgl. in Bild 5 unten). Dies ist die klassische Konfiguration eines Pattern Associators [7]. Optional können noch Hidden-Layer eingefügt werden. Für die Aktivierungsfunktion hat sich bei den bisherigen Untersuchungen an exemplarischen Daten die sigmoide Funktion nach [8] als besonders vorteilhaft herausgestellt.

8 Ergebnisse

Zum Entstehungszeitpunkt dieses Beitrags wurde bereits eine modulare Trainings- und Evaluierungssoftware erstellt, so dass erste Versuche mit realen Daten durchgeführt werden konnten. Eine besonders schwierige Aufgabe war die Beschaffung der Daten. Besonders Zeitaufwendig war die Erfassung und Verknüpfung der Daten. Hinzu kommt, dass die Erzeugung der Daten in den Werkstätten an sich nicht in der für ein Lernsystem nötigen Qualität stattfindet. Nur mit einigem Aufwand konnten die Daten verknüpft und ein Algorithmus entwickelt werden, der aus den Daten möglichst „qualitativ hochwertige“ Datensätze herausfiltert.

Ausgangsbasis für einen ersten Versuch war ein große Zahl realer Reparaturfällen. Als Symptome wurden hier lediglich DTCs und als Maßnahmen Komponentenbezeichnungen⁴ verwendet. In Bild 7 ist beispielhaft ein Netz aus der Netzmenge abgebildet. Dunkle Verbindungen bedeuten eine große Gewichtung, helle Verbindungen eine geringe Gewichtung.

⁴ Komponentenbezeichnungen = Ein für statistische Auswertungen eingeführter Katalog mit Reparaturmaßnahmen, die je einer Komponente z. B. Ölstandssensor zugeordnet sind.

Eine gute Möglichkeit, die Fähigkeiten eines Neuronalen Netzes hinsichtlich einer konkreten Maßnahme zu evaluieren ist die Gegenüberstellung der Netzverbindungsgewichte mit einem Histogramm der Symptome. Für die Komponente Ölstandssensor ist dies veranschaulicht in Bild 8 dargestellt. Die hellen Balken stellen dabei die Anzahl der Fälle dar, in denen das Symptom bei der betreffenden Komponente auftritt, die grauen Balken die aus der Signifikanzmatrix ermittelte Signifikanzklasse⁵. Die dunklen Balken stellen nun das




Bild 7: Neuronales Netz mit codierten Symptomen und Maßnahmen.

Verbindungsgewicht zwischen dem entsprechenden Symptomneuron und dem Maßnahmenneuron dar. Wird nun das am häufigsten vorkommende Symptom mit der ID S1 (Lenkwinkelsensor) betrachtet, so ist anhand der Fehlertexte schnell vermutbar, dass der Lenkwinkelsensor offensichtlich nichts mit dem Ölstandssensor zu tun hat. Trotzdem tritt dieses Symptom statistisch am häufigsten auf. Wird die Signifikanzklasse betrachtet, lässt sich erahnen, dass der Einfluss des Symptoms geringer ist. Wird nun das Netzgewicht

⁵ Signifikanzklasse = $(0,05 - p\text{-Wert}) \cdot 100$. 5 = hoch signifikant, 0 = nicht signifikant

betrachtet (0,005), so ist die Aussage des Netzes, dass dieses Symptom keinen Einfluss auf die Maßnahme hat. Als Vergleich soll nun das Symptom mit der ID S5 (Motorelektronik II, Ölstand-/temperatursensor) betrachtet werden. Die Fallzahl ist relativ gering, trotzdem ist das Verbindungsgewicht sehr hoch. Wird dies nun den Fehlertexten gegenübergestellt, so ist dies plausibel. Für alle weiteren Symptome kann dies äquivalent validiert werden.

In Kürze werden weitere Versuche mit größeren und umfangreicheren Datensätzen unter Einbeziehung der Kontextinformationen und detaillierteren Maßnahmen durchgeführt. Weiterhin steht die Entwicklung einer Validierungsmethode für die Diagnosegüte aus.




Bild 8: Vergleich Symptomhistogramm vs. Verbindungsgewichte für die Komponente Ölstandssensor.

9 Zusammenfassung

Die bisherigen Ergebnisse lassen erste positive Rückschlüsse auf die Leistungsfähigkeit von Künstlichen Neuronalen Netzen in einem erfahrungsbasierten Diagnosesystem zu. Sie zeigen, dass Neuronale Netze selbst in unscharfen Daten automatisch Muster und Zusammenhänge erkennen, die nicht nur für eine Diagnose in der Werkstatt genutzt werden können. Die mittels KNN erzeugten Modelle eröffnen eine Bandbreite an neuen Möglichkeiten die Daten zu verstehen und z. B. für qualitätssteigernde Maßnahmen einzusetzen.

Darüber hinaus stellt ein erfahrungsbasiertes Diagnosesystem in der heutigen Diagnose-landschaft eine hervorragende Ergänzung zu den bisher eingesetzten Diagnosesystemen (z. B. GFS) dar. Es besitzt die entscheidenden Vorteile in der AUTOMATISCHEN Generierung und Adaptierung von Diagnosewissen. Ein solches Diagnosesystem ermöglicht somit auch in Zukunft immer komplexer werdende Fahrzeuge mit zahlreicher werdenden Varianten und verkürzten Entwicklungszyklen effizient instand zu setzen.

Literatur

- [1] Abuosba, Mohammad: Fahrzeug-Diagnose mit System. In: Sonderdruck aus Wissensmanagement 8/30 (2004)
- [2] Hack, Christian ; Drenkhahn, Georg ; Nickles, Jochen: Vernetzte Funktionen beherrschen - Diagnoseanforderung zur Bewältigung der Komplexität vernetzter Fahrzeugsysteme. In: Automotive, Messen und Testen (2006)
- [3] Rumpe, Bernhard ; Schiffers, Jutta: Herausforderungen an die Diagnose - Integration der Diagnose in die Steuergeräteentwicklung. In: ZfAW. Zeitschrift für die gesamte Wertschöpfungskette Automobilwirtschaft (2006), S. 65–69
- [4] ISO 15031, Road vehicles - Communication between vehicle and external equipment for emissions-related diagnostics, ISO 2006
- [5] Isermann, R: Modellgestützte Steuerung, Regelung und Diagnose von Verbrennungsmotoren, Springer 2003
- [6] Callan, Robert: Neuronale Netze im Klartext. Pearson Studium Deutschland GmbH, 2006
- [7] Raul Rojas: Theorie der neuronalen Netze. Springer-Verlag, 1993
- [8] Christian Borgelt, Frank Klawonn, Rudolf Kruse: Neuronale Netze und Fuzzy-Systeme, 1994